

N. Kokan, J. Tomić, A. Grubišić: Sustav Moodle...

Šk. vjesn. 63, 3 (2014) 367-379

UDK 372.881.116.342:004.85

Prethodno priopćenje

Prihvaćeno: 23. svibnja 2014.

Nataša KOKAN***Jelena TOMIĆ******Ani GRUBIŠIĆ*****

SUSTAV MOODLE U NASTAVI HRVATSKOG JEZIKA

Sažetak: U radu su prikazani rezultati istraživanja o učinku učenja i poučavanja učenika sedmih razreda osnovne škole pomoću sustava „Moodle“ za područno znanje nastavnog predmeta hrvatski jezik. Istraživanje su provele učiteljice hrvatskoga jezika i studentice druge godine diplomskog studija informatike Prirodoslovno-matematičkog fakulteta Sveučilišta u Splitu iz kolegija „Vrednovanje sustava e-učenja“ u zimskom semestru akademske godine 2011./2012. Obuhvaćen je uzorak od dvaju razrednih odjela (43-oje učenika) sedmih razreda OŠ Lučac u Splitu. Istraživanje je pokazalo da postoji mala veličina učinka, tj. da primjena ovakvog oblika nastave ne pridonosi statistički značajno povećanju učinkovitosti u procesu učenja i poučavanja. Uporaba suvremenih tehnologija u nastavi hrvatskoga jezika u kombinaciji s tradicionalnom nastavom bio bi najbolji izbor jer pomaže učiteljima da lakše organiziraju kvalitetnu nastavu.

Ključne riječi: e-učenje, sustav za upravljanje učenjem, vrednovanje.

1. Uvod

Razvojem modernih tehnologija potpuno se promijenio život pojedinca i društva u cjelini. Od ovih procesa nije izuzeto učenje ni poučavanje, kako u osnovnim tako i u srednjim školama pa sve do fakulteta. Zahtjevi za promjenama u nastavi postaju sve očitiji i logičan su slijed tehnološkoga razvoja, stvarnosti u kojoj učenici žive. Tradicionalni načini poučavanja ne mogu odgovoriti na izazove zbilje suvremenoga učenika. Za poboljšanje obrazovnih postignuća potrebna je primjena alternativnih metoda i postupaka poučavanja, a e-učenje (engl.

e-learning), kao presjek informacijske i komunikacijske tehnologije i obrazovanja, jedna je od tih metoda (Stankov i sur., 2004).

Svrha vrednovanja sustava e-učenja jest ispitivanje na koji način uporaba tog sustava podupire proces učenja i poučavanja. Posebno je važno naglasiti da sva programska podrška koja se upotrebljava u obrazovne svrhe treba biti vrednovana prije korištenja u procesu učenja i poučavanja (Grubišić, 2007). Da bismo usporedili tradicionalni oblik poučavanja hrvatskoga jezika s učenjem uz pomoć sustava za e-učenje *Moodle (Modular Object-Oriented Dynamic Learning Environment, <<http://moodle.org>>)*, proveli smo istraživanje na uzorku od 43-oje učenika sedmih razreda.

2. E-učenje i sustav moodle

E-učenje paradigma je učenja pomoću različitih uređaja koji se temelje na elektroničkoj tehnologiji. Prednosti e-učenja su velike: brzina učenja, lokacija, vrijeme, mogućnosti kombinacije individualnoga učenja, učenja u grupi, učenja uz mentore, fleksibilnost sadržaja, integracija, pristup drugim sadržajima itd. U usporedbi s tradicionalnom nastavom prednosti su brojne, počevši od toga da se sadržajima može pristupiti i nakon završetka formalnog dijela obrazovanja do toga da snažno motivira učenike i potiče ih na interakciju.

U ovom radu prikazani su rezultati istraživanja o učinkovitosti sustava *Moodle*, kao jednog primjerka posebne kategorije sustava e-učenja – sustava za upravljanje učenjem (engl. *Learning Management System, LMS*) (Stankov, 2010.). *Moodle* je modularan sustav, što znači da se sastoji od manjih cjelina, a omogućava izradu ili integriranje unaprijed izrađenih elektronskih nastavnih sadržaja, planiranje nastave, upravljanje korisnicima, provjeru znanja i ocjenjivanje, praćenje aktivnosti i komunikaciju. Svoju popularnost u pedagoškoj primjeni zahvaljuje jednostavnoj i brznoj instalaciji, malim zahtjevima za resursima računala, fleksibilnosti, brzini i činjenici da je besplatan (Bosnić, 2006; Stanford, 2008).

3. Metodologija istraživanja

Metodologija istraživanja obuhvaća eksperimentalno istraživanje koje su proveli učitelji hrvatskoga jezika OŠ „Lučac“ i studenti druge godine diplomskoga studija informatike Prirodoslovno-matematičkoga fakulteta Sveučilišta u Splitu iz kolegija „Vrednovanje sustava za e-učenje“.

Osnovni cilj eksperimenta jest utvrditi postoji li, koliki je i kakav je utjecaj određene nezavisne varijable (one koje djeluju, koje predstavljaju uzroke) na

određenu zavisnu varijablu (one na koje se djeluje, koje predstavljaju posljedice) (Mužić, 1977; Shadish i sur., 2002).

3.1. Eksperimentalno istraživanje

Prikazat ćemo pojedinosti provedbe eksperimenta kojim smo utvrdili učinak učenja i poučavanja učenika uz pomoć sustava *Moodle* za područno znanje nastavnog predmeta hrvatski jezik.

Cilj istraživanja jest ispitati razliku između računalom potpomognute nastave uz sustav *Moodle* i tradicionalne nastave hrvatskoga jezika u sedmom razredu te na osnovu rezultata utvrditi koji od dvaju oblika učenja i poučavanja ima bolji učinak.

Zadatci su istraživanja bili:

- zadatcima objektivnoga tipa (ZOT1) ispitati inicijalno stanje
- upoznati učenike sa sadržajem nastavne cjeline „Nezavisno složene rečenice“ koja se sastoji od nastavnih jedinica „Sastavna i rastavna rečenica“, „Isključna i zaključna rečenica“ i „Suprotna rečenica“
- realizirati nastavu na tradicionalan način
- upoznati učenike sa sustavom *Moodle*
- realizirati nastavu pomoću sustava *Moodle*
- ispitati završno stanje zadatcima objektivnog tipa (ZOT2 i ZOT3).

Na temelju navedenog cilja i zadataka postavili smo **hipotezu istraživanja**: učenici koji su poučavani pomoću sustava *Moodle* imat će bolji učinak od učenika koji su poučavani na tradicionalan način.

Hipoteza se rastavlja na manje dijelove koji se preformuliraju u formu nul-hipoteze. Nul-hipoteza (Petz, 2004) znači da za neko svojstvo „nema razlike“ između skupina podvrgnutim različitom utjecaju. Hipoteza je ovog istraživanja složena pa smo je podijelili na sljedeće **nul-hipoteze**.

H1: Ne postoji statistički značajna razlika u završnom (ZOT2) mjerenju učinka tradicionalne nastave (kontrolne skupine) i učinka nastave uz pomoć računala (eksperimentalne skupine).

H2: Ne postoji statistički značajna razlika u završnom (ZOT3) mjerenju učinka tradicionalne nastave (kontrolne skupine) i učinka nastave uz pomoć računala (eksperimentalne skupine).

H3: Ne postoji statistički značajna razlika u aritmetičkoj sredini završnih mjerenja (ZOT2 i ZOT3) učinka tradicionalne nastave (kontrolne skupine) i učinka nastave uz pomoć računala (eksperimentalne skupine).

Mjesto istraživanja bila je Osnovna škola „Lučac“ u Splitu.

Vrijeme istraživanja bilo je od 23. do 26. siječnja 2012.

Uzorak istraživanja činilo je 43-oje učenika dvaju razrednih odjela, 7. a i 7. c. Razredni odjel 7. a bio je eksperimentalna skupina (E skupina), a razredni odjel 7. c bio je kontrolna skupina (K skupina).

Instrumenti za provedbu istraživanja zadatci su objektivnog tipa sastavljeni u dvije usporedne forme: ZOT1 za utvrđivanje inicijalnoga stanja te ZOT2 i ZOT3 za utvrđivanje konačnoga stanja. Zadatci ZOT-a1 i ZOT-a2 imali su ista pitanja koja su pripremile učiteljice hrvatskoga jezika, a zadatci u ZOT-u 3 pripremljeni su prema Pismenim ispitima za 7. razred (Šojat, 2011).

Tijek istraživanja prikazan je u tablici 1 s nadnevcima realizacije nastavnih sadržaja te realizacije ZOT-a1, ZOT-a2 i ZOT-a3 eksperimentalne i kontrolne skupine. ZOT1 proveo se prije realizacije nastave kako bi se utvrdilo inicijalno stanje, tj. predznanje učenika. ZOT2 i ZOT3 provodili su se nakon tradicionalnog poučavanja i poučavanja pomoću sustava *Moodle* kako bi se provjerilo završno stanje, tj. usvojenost sadržaja.

Tablica 1 – Tijek istraživanja

	realizacija ZOT1	realizacija nastave	realizacija ZOT2	realizacija ZOT3
E-skupina 7.a	20. 1. 2012.	23. 1. 2012. nastavna jedinica „Sastavna i rastavna rečenica“	16. 2. 2012.	27. 2. 2012.
		24. 1. 2012. nastavna jedinica „Suprotna rečenica“		
		26. 1. 2012. nastavna jedinica „Isključna i zaključna rečenica“		
K-skupina 7.c	20. 1. 2012.	23. 1. 2012. nastavna jedinica „Sastavna i rastavna rečenica“	16. 2. 2012.	27. 2. 2012.
		24. 1. 2012. nastavna jedinica „Suprotna rečenica“		
		26. 1. 2012. nastavna jedinica „Isključna i zaključna rečenica“		

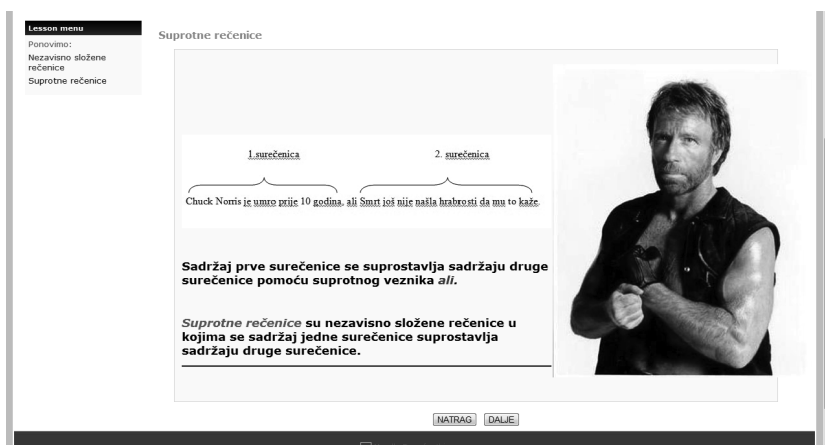
3.2. Analiza nastavnih sadržaja

Na početku sata upoznali smo učenike sa sustavom *Moodle* i načinom na koji se njime mogu koristiti. Svaki učenik dobio je svoje korisničko ime i lozinku pomoću kojih su učenici pristupili sustavu *Moodle*.

Na sustavu *Moodle* postavljen je sadržaj nastavne cjeline „Nezavisno složene rečenice“. Zadatak učenika bio je da pristupe svakoj od nastavnih jedinica navedene nastavne cjeline i započnu s učenjem i poučavanjem uz pomoć lekcija oblikovanih u sustavu. Na slici 1 prikazan je primjer sadržaja nastavne jedinice u sustavu *Moodle*.

Nakon što su se učili i poučavali na postavljenim nastavnim sadržajima, učenici su pristupili testu koji su rješavali onoliko puta koliko su htjeli, a imali su mogućnost pristupa sustavu i kod kuće. Na slici 2 prikazan je primjer testa koji su učenici rješavali.

Slika 1 – Primjer nastavnoga sadržaja u sustavu „Moodle“



Slika 2 – Primjer testa u sustavu „Moodle“




4. Prikaz i analiza rezultata

Na početku svake obrade rezultata eksperimenta potrebno je provjeriti statističku ekvivalentnost ispitnih skupina prema rezultatima inicijalnog testa (u našem eksperimentu to je test ZOT1). Budući da se nije moglo prebacivati učenike iz jedne skupine u drugu jer se radi o razrednim odjeljenjima, za postojanje statističke ekvivalentnosti mogli smo intervenirati jedino u odabir ispitanika unutar razrednog odjeljenja. Metodom izjednačavanja u rasponu ± 5 bodova (Grubišić, 2007) iz eksperimentalne je skupine izbačeno devet učenika, a iz kontrolne tri učenika te su dobivene jednakobrojne skupine.


Pojedinačni rezultati testova za svakog od ispitanika navedeni su u tablici 2.

Tablica 2 – Rezultati testova

Rezultati kontrolne skupine



Rezultati eksperimentalne skupine



Nakon provedenog izjednačavanja skupina prema rezultatima inicijalnog testa, pristupilo se statističkoj provjeri ekvivalentnosti kontrolne i eksperimentalne skupine. Cijela statistička analiza napravljena je u sustavu EVEDIN (*E*valuation of *E*ducational *I*nfluence) (Grubišić, 2007).

U tablici 3 prikazane su vrijednosti mjera centralne tendencije te t-vrijednost koja određuje statističku ekvivalentnost skupina. Usporedbe radi, isti je izračun napravljen nad rezultatima prije i poslije primjene metode izjednačavanja ispitnih skupina u rasponu ± 5 bodova.

Tablica 3 – Statistička ekvivalentnost skupina prije i poslije primjene metode izjednačavanja u rasponu

	prije izjednačavanja u rasponu		poslije izjednačavanja u rasponu	
	kontrolna skupina	eksperimentalna skupina	kontrolna skupina	eksperimentalna skupina
broj ispitanika N	19	24	16	16
aritmetička sredina AS	58,053	77,292	65,625	73,8125
standardna devijacija SD	25,030	13,528	17,727	14,824
stupnjevi slobode	43		30	
razina statističke značajnosti	$\alpha=0.05$		$\alpha=0.05$	
t-vrijednost (granična t-vrijednost)	-3,019 (2,014)		-1,417 (2,042)	


Zaključujemo da smo metodom izjednačavanja u rasponu dobili statistički ekvivalentne skupine i da se daljnja analiza podataka obavlja na dobivenim podgrupama inicijalnih ispitnih skupina.


Za potrebe određivanja učinkovitosti primjene sustava *Moodle* u nastavi hrvatskog jezika u sedmom razredu osnovne škole, postavili smo nul-hipoteze koje daljnjom statističkom analizom treba prihvatiti ili odbaciti. Da bismo nul-hipoteze mogli prihvatiti ili odbaciti, potrebno je izračunati razliku između rezultata završnih testova ZOT2 i ZOT3 (kao i prosjeka njihovih vrijednosti) s inicijalnim testom ZOT1 za kontrolnu i eksperimentalnu skupinu. Zatim je potrebno izračunati t-vrijednost da bi se mogla prihvatiti ili odbaciti odgovarajuća nul-hipoteza. Kod svih triju nul-hipoteza broj ispitanika N u kontrolnoj i eksperimentalnoj skupini iznosi 16, stupnjevi slobode df su 30, razina statističke značajnosti α je 0,05, a granična t-vrijednost je 2,014. U tablici 4 su prikazani su rezultati statističke analize potrebne za prihvaćanje ili odbacivanje nul-hipoteza.

Tablica 4 – Rezultati statističke analize potrebne za prihvaćanje ili odbacivanje nul-hipoteza

nul-hipoteza H1 \square ZOT2-ZOT1		
	kontrolna skupina	eksperimentalna skupina
aritmetička sredina AS	2,250	4,312
standardna devijacija SD	11,733	11,019
t-vrijednost	-0,513	
nul-hipoteza h2 \square ZOT3-ZOT1		
	kontrolna skupina	eksperimentalna skupina
aritmetička sredina AS	-0,063	-5,313
standardna devijacija SD	15,903	15,482
t-vrijednost	0,946	
nul-hipoteza h3 \square (prosjek ZOT2 i ZOT3)-ZOT1		
	kontrolna skupina	eksperimentalna skupina
aritmetička sredina AS	1,094	-0,500
standardna devijacija SD	12,147	11,912
t-vrijednost	0,375	

Usporedba aritmetičkih sredina i varijacija dviju grupa vizualno se prikazuje uz pomoć tzv. *box-and-whisker plots* i histogramima koji omogućavaju intuitivno vizualiziranje veličine povezanosti dviju skupina (slika 3).

Slika 3 – Grafički prikaz rezultata eksperimenta



Dok napravljeni testovi značajnosti govore o vjerojatnosti kojom se rezultati na testovima eksperimentalne grupe razlikuju od slučajnih rezultata, mjere veličine učinka govore o relativnoj jačini eksperimentalnog faktora (u našem slučaju sustava *Moodle*). Na temelju vrijednosti aritmetičkih sredina i standardnih devijacija navedenih u prethodnoj tablici, izračunali smo sljedeće veličine učinka (tablica 5):

Tablica 5 – Veličine učinka dobivene iz rezultata odgovarajućih završnih testova

test	veličina učinka
ZOT2	0,176
ZOT3	-0,330
prosjeck ZOT2 i ZOT3	-0,131

Nakon analize rezultata potrebno je napraviti njihovu interpretaciju u kontekstu provedenog istraživanja.

5. Interpretacija rezultata

Rezultati koji se dobiju primjenom neke metode za vrednovanje čine osnovu za pronalaženje odgovora na pitanje koje se postavlja prije samog istraživanja, tj. za interpretaciju tih rezultata. Ponekad je teško razlučiti analizu podataka od interpretacije. Analizom podataka pojedinačni se podatci sređuju i u njima se pronalaze smislene cjeline, tj. dolazi se do rezultata, dok interpretacija polazi od rezultata, uočava njihov značaj, traži se njihova međusobna povezanost. Dakle, bez interpretacije svi koraci koji su prethodili dobivanju rezultata postaju nepotrebni (Mužić, 1977).

Na temelju analize rezultata t-testa iz tablice 4, donosimo sljedeće zaključke o prihvatanju ili odbacivanju postavljenih nul-hipoteza:

Nul-hipoteza H1 prihvaća se, tj. razlika nije statistički značajna!

Eksperimentalna skupina statistički je neznačajno bolja od kontrolne za $\alpha=0.05$!

Nul-hipoteza H2 prihvaća se, tj. razlika nije statistički značajna!

Kontrolna skupina statistički je neznačajno bolja od eksperimentalne za $\alpha=0.05$!

Nul-hipoteza H3 prihvaća se, tj. razlika nije statistički značajna!

Kontrolna skupina statistički je neznačajno bolja od eksperimentalne za $\alpha=0.05$!

Kao što možemo vidjeti, prosječna veličina učinka (tablica 5) dobivenog istraživanjem u kojem smo u obzir uzeli ispitanike koji su preostali nakon uparivanja u rasponu ± 5 iznosi -0.09. Najprije možemo primijetiti da je veličina učinka negativna, što nam pokazuje da je prema (Petz, 2004) kontrolna skupina bolja od eksperimentalne, tj. da je pokazala bolje rezultate. Kako je nama veličina učinka mala (Cohen, 1969), tj. manja od 0.2, a očekivali smo značajnije rezultate, bilo bi potrebno ispitati što je moglo utjecati na naše istraživanje.

Prema (Mužić, 1977) postoji više tipova pogrešaka koje mogu utjecati na rezultate eksperimenta. Jedan tip pogreške leži u subjektima (u našem slučaju učenicima) na kojima se vrši eksperiment. Podjelom na skupine može doći do toga da se razlikuju po predznanju, općoj mentalnoj sposobnosti, marljivosti itd. Od navedenog je samo predznanje moglo biti provjereno inicijalnim testom, što smo mi i učinili. Pokazalo se da nema nikakvih razlika između dviju skupina prije početka učenja (u predznanju iz područnog znanja). Tijekom provjere metričkih karakteristika testova često se javljao problem malog uzorka učenika na kojem se provodilo naše istraživanje.

Jedan od mogućih razloga slabijih rezultata eksperimentalne skupine mogla bi biti i nezainteresiranost učenika. Kako bismo to provjerili, neka od pitanja koja smo postavili u inicijalnom testu, a odgovorena su jako loše ili dosta dobro, ponovili smo i u završnom testu. Pretpostavljali smo da će učenici na ta „ista“ pitanja odgovoriti puno bolje. Kontrolna skupina pokazala je mali napredak, ali kod eksperimentalne skupine možemo prepoznati nezainteresiranost jer je na ta pitanja odgovorila lošije u završnom testu nego u inicijalnom testu, što je nevjerojatno.

Na temelju promatranja ponašanja učenika tijekom trajanja cijelog eksperimenta može se pretpostaviti da dio učenika nije bio dovoljno motiviran,

a kako se radi o malom uzorku, to može imati još i veći utjecaj na rezultate. Problem odustajanja jedan je od problema prilikom istraživanja učenja na daljinu koje navode Phillips i Merisotis (Phillips i Merisotis, 1999), istražujući zašto se dovoljno ne ispituju razlozi zbog kojih učenici odustaju od takvog načina učenja. Problem odustajanja ovdje se spominje jer smatramo da je vezan uz nedovoljnu motiviranost studenata, ali kako ovo istraživanje nije trajalo tijekom cijelog polugodišta, nije ga bilo moguće istražiti.

6. Zaključak

LMS sustavi (u našem slučaju *Moodle*) ne mogu u cijelosti zamijeniti profesora, ali mogu olakšati rad profesora i ujedno im omogućiti više vremena potrebnog za razgovor s učenicima, raspravu o određenim problemima te češće provjere znanja koje je inače nemoguće provoditi zbog nedostatka vremena u tradicionalnoj nastavi.

Budući da je naše istraživanje pokazalo da ne postoji statistički značajna razlika između tradicionalne nastave i nastave primjenom sustava *Moodle*, smatramo da bi najbolja opcija nastave bila njihova kombinacija. Naime, u današnje vrijeme profesori, zbog sve većeg obujma gradiva za koje je predviđen određen broj sati, nemaju vremena za ponavljanje određenog znanja kao ni za raspravu s učenicima o mogućim nejasnoćama. Zbog takvih ograničenja učenici mogu ostvariti loše rezultate na ispitima. Upravo zbog takvih problema LMS sustavi mogu pomoći profesorima da lakše organiziraju kvalitetniju nastavu u kojoj bi bilo više vremena za posvetiti se potrebama učenika.

Potrebno je nastaviti s istraživanjem na većem uzorku učenika te ispitati učinkovitost sustava na drugim nastavnim sadržajima predmeta hrvatski jezik.

Literatura

1. Bosnić, I. (2006): *Moodle, priručnik za seminar*. Hrvatska udruga za otvorene sustave i Internet.
2. Cohen, J. (1969): *Statistical Power Analysis for the Behavioral Sciences*. NY: Academic Press.
3. Grubišić, A. (2007): *Vrednovanje učinka inteligentnih sustava e-učenja*. Magistarski rad, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu.
4. Mužić, V. (1977): *Metodologija pedagoških istraživanja*, Svjetlost, Sarajevo.

5. Petz, B. (2004): *Osnovne statističke metode za nematematičare*. Naklada Slap, Jastrebarsko.
6. Phillips, R.; Merisotis, J. (1999): *What's the difference? A review of contemporary research on the effectiveness of distance learning in higher education*. Washington, DC: Institute for Higher Education Policy.
7. Shadish, W. R.; Cook, T. D.; Campbell, D. T. (2002): *Experimental and quasi-experimental design for generalized causal inference*. Boston: Houghton-Mifflin.
8. Stanford, J. (2008): „In the mood for Moodle“. *English Teaching Professional* (54).
9. Stankov, S. (2010): *Intelligentni tutorski sustavi*. Interna skripta, Prirodoslovno-matematički fakultet, Sveučilište u Splitu.
10. Stankov, S.; Grubišić, A.; Žitko, B. (2004): „E-learning paradigm & Intelligent tutoring systems“. U: Kniewald, Z. (ur.), *Annual 2004 of the Croatian Academy of Engineering*, Zagreb: Hrvatska akademija inženjera, 21 – 31.
11. Šojat, A. (2010): *Pismene provjere znanja hrvatskoga jezika (jezik, književnost, medijska kultura, lektira) za peti, šesti, sedmi i osmi razred s točnim odgovorima i mjerilima vrjednovanja (priručnik za učitelje)*. Zagreb: Školska knjiga.

Nataša Kokan*

Jelena Tomić**

Ani Grubišić**

USING THE MOODLE SYSTEM IN TEACHING THE CROATIAN LANGUAGE

Summary: *This paper presents the results of a research on the impact of using the system Moodle in learning and teaching seventh graders the domain knowledge of the course in the Croatian language. The research was conducted by the Croatian language teachers and the second year graduate students from the Faculty of Natural Sciences and Mathematics, University of Split, that have enrolled on the course "Evaluation of e-learning systems" in the winter semester of the academic year 2011/2012. The sample included two seventh grade classes (43 students) from Elementary School of Lučac in Split. The research has shown that there is a small effect size, i.e. the usage of this form of teaching does not contribute significantly to improving the efficiency in the learning and teaching process. The use of modern technologies in teaching Croatian in combination with traditional approaches would be the best choice as this helps teachers to organize high-quality teaching more easily.*

Keywords: *e-learning, learning management system, evaluation.*

* Nataša Kokan

Osnovna škola „Lučac“ u Splitu

kokannatasa@net.hr

**Jelena Tomić

Osnovna škola „Lučac“ u Splitu

jelenat8b@gmail.com

***doc.dr.sc. Ani Grubišić

Sveučilište u Splitu

Prirodoslovno-matematički fakultet

Odjel za informatiku

ani.grubisic@pmfst.hr

*Nataša Kokan

Primary School of Lučac, Split

kokannatasa@net.hr

**Jelena Tomić

Primary School of Lučac, Split

jelenat8b@gmail.com

***Ani Grubišić, PhD, senior lecturer

University of Split

Faculty of Natural Sciences and Mathematics

Department of Informatics

ani.grubisic@pmfst.hr